

# Klasické metody redukce dimenze dat

1. Připomenutí PCA (Principal Component Analysis, rozklad na hlavní komponenty)
2. ICA (Independent Component Analysis, rozklad na nezávislé komponenty)  
[Jutten & Héroult 1991]
3. Fisherova diskriminační analýza

## Literatura k tématu

- [1] R.O. Duda – P.E. Hart – D.G. Stork. Pattern Classification. John Wiley & Sons, 2001.
- [1] A. Hyvärinen – E. Oja. Independent Component Analysis: Algorithms and Applications. *Neural Networks*, 13(4-5):411-430, 2000.

# PCA: Rozklad na hlavní komponenty

Máme množinu bodů  $\mathbf{x}_1, \dots, \mathbf{x}_k$  v prostoru dimenze  $d$ , z bodů vytvoříme  $d \times k$  matici  $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_k]$

Hledáme nejlepší reprezentaci  $\mathbf{X}$  v prostoru dimenze  $s < d$

1. Nejlepší reprezentace pro  $s = 0$  minimalizuje energii

$$J_0 = \sum_{i=1}^k \|\mathbf{x}_i - \mathbf{x}_0\|^2,$$


kde řešením je

$$\mathbf{x}_0 = \frac{1}{k} \sum_{i=1}^k \mathbf{x}_i$$

$$P(\varepsilon | x_0) = \prod_{i=1}^k P(\varepsilon_i | x_0)^N$$

$P \approx \frac{1}{T} e^{-\varepsilon_i^2}$

důkaz:  $\ast 1$



# PCA: pokračování

2. Nejlepší reprezentace při  $s = 1$  je průmět na přímku

$$\mathbf{y}_i = \mathbf{x}_0 + t_i \mathbf{w}, \quad \text{kde } \mathbf{w} \text{ je vektor dimenze } d \text{ a } \|\mathbf{w}\| = 1$$

Parametry  $t_i$ ,  $i = 1, 2, \dots, k$  a  $\mathbf{w}$  minimalizují energii

$$\begin{aligned} J(t_1, \dots, t_k, \mathbf{w}) &= \sum_{i=1}^k \|\mathbf{x}_0 + t_i \mathbf{w} - \mathbf{x}_i\|^2 = \sum_i \|t_i \mathbf{w} - \bar{\mathbf{x}}_i\|^2 = \sum_i (t_i \mathbf{w} - \bar{\mathbf{x}}_i)^\top (t_i \mathbf{w} - \bar{\mathbf{x}}_i) = \\ &= \sum_i \left( t_i^2 - 2t_i \mathbf{w}^\top \bar{\mathbf{x}}_i + \bar{\mathbf{x}}_i^\top \bar{\mathbf{x}}_i \right) \end{aligned}$$

z  $\frac{\partial J}{\partial t_i} = 0$  dostaneme  $t_i = \mathbf{w}^\top \bar{\mathbf{x}}_i = \bar{\mathbf{x}}_i^\top \mathbf{w}$ . Po dosazení

$$J(t_1, \dots, t_k, \mathbf{w}) = \dots = \sum_i \bar{\mathbf{x}}_i^\top \bar{\mathbf{x}}_i - \mathbf{w}^\top \left( \sum_i \bar{\mathbf{x}}_i \bar{\mathbf{x}}_i^\top \right) \mathbf{w} = \sigma^2 - \mathbf{w}^\top \mathbf{S} \mathbf{w},$$

kde  $\mathbf{S}$  je  $d \times d$  kovarianční matice  $\mathbf{S} = \mathbf{X}\mathbf{X}^\top$

# PCA: pokračování

Hledáme minimum  $J$  za podmínky  $\|\mathbf{w}\|^2 = 1$

$$\mathbf{w}^* = \arg \min_{\mathbf{w}} (\sigma^2 - \mathbf{w}^\top \mathbf{S} \mathbf{w} + \lambda(\mathbf{w}^\top \mathbf{w} - 1))$$

z  $\frac{\partial J}{\partial \mathbf{w}} = 0$  dostaneme  $2\mathbf{S}\mathbf{w} - 2\lambda\mathbf{w} = 0$ , z čehož plyne

$$\mathbf{S}\mathbf{w} = \lambda\mathbf{w}$$

$\mathbf{w}$  musí být vlastním vektorem  $\mathbf{S} = \mathbf{X}\mathbf{X}^\top$  odpovídajícím největšímu vlastnímu číslu.

3. při  $s > 1$  postupujeme obdobně, promítáme do  $s$ -dimenzionální nadroviny

$$\mathbf{y}_i = \mathbf{x}_0 + \sum_{j=1}^s t_i^j \mathbf{w}^j$$

a zjistíme, že  $\mathbf{w}^j$  jsou rovny **ortogonálním vlastním vektorům**  $\mathbf{S}$  odpovídající  $s$  největším vlastním číslům.

